

Моделирование маркетингового микса как инструмент оценки эффективности проведения рекламных кампаний

Исследование выполнено при финансовой поддержке Российского научного фонда в рамках научного проекта № 23-18-00409

Нуриев Ислам Бабаш Оглы

Аспирант, медиа-аналитик VK,
Новосибирский государственный университет, г. Новосибирск, Российская Федерация
E-mail: i.nuriev@gsu.ru

Душенин Александр Игоревич

Кандидат экономических наук, преподаватель¹, младший научный сотрудник²,
¹Институт экономики и организации промышленного производства СО РАН, г. Новосибирск, Российская Федерация
²Новосибирский государственный университет, г. Новосибирск, Российская Федерация
E-mail: a.dushenin@gsu.ru

Ибрагимов Наимджон Мулабоевич

Доктор экономических наук, доцент, профессор^{1,3}, ведущий научный сотрудник²
¹Новосибирский государственный университет, г. Новосибирск, Российская Федерация
²Институт экономики и организации промышленного производства СО РАН, г. Новосибирск, Российская Федерация
³Новосибирский государственный технический университет, г. Новосибирск, Российская Федерация
E-mail: naimdjon.ibragimov@gsu.ru

КЛЮЧЕВЫЕ СЛОВА

моделирование
маркетингового микса,
байесовский подход,
эффект синергии,
эффект воронки, эффект
насыщения, эффект
отложенного воздействия,
рекламные каналы, causal
inference

АННОТАЦИЯ

В современном бизнес-окружении компании осуществляют значительные инвестиции в разнообразные маркетинговые каналы, начиная от традиционных (телевизионная реклама, наружная реклама, печатные СМИ и т.п.) и заканчивая современными цифровыми форматами (контекстная реклама, маркетинг с участием блогеров, социальные сети, e-mail кампании и т.д.). Такой широкий спектр каналов создает сложную систему маркетинговых коммуникаций, что в свою очередь обуславливает необходимость точной и систематической оценки вклада каждого отдельного канала, а также их взаимодействий в достижении бизнес-целей и максимизации эффективности маркетинговых инвестиций. В настоящей работе представлены теоретические основы концепции моделирования маркетингового микса (МММ), которая направлена на моделирование и анализ влияния отдельных компонентов маркетинговых стратегий на итоговые показатели бизнеса, такие как продажи, прибыль или рыночная доля. В ходе исследования особое внимание уделяется изучению эффектов взаимодействия между каналами маркетинга, а также их динамическим аспектам: эффектам синергии, насыщения, а также включению отложенных во времени воздействий маркетинговых активностей, что позволяет более точно оценивать временные цепочки и взаимосвязи между вложениями и результатами. Кроме того, в работе подробно рассматриваются байесовские методы. Эти методы позволяют эффективно интегрировать априорные знания и экспертные оценки в модели, что особенно важно в условиях ограниченности данных, высокой мультиколлинеарности между каналами или наличии неопределенностей. Байесовский подход способствует не только повышению точности оценок, но и обеспечивает проведение надежных интервальных оценок, а также легко моделирует сложные, иерархические и нелинейные взаимодействия компонентов маркетингового микса, делая анализ более гибким и адаптивным к разнообразным условиям.

JEL codes: M31, C11, C44

DOI: <https://doi.org/10.52957/2221-3260-2025-11-53-70>

Для цитирования: Нуриев, И.Б. Моделирование маркетингового микса как инструмент оценки эффективности проведения рекламных кампаний / И.Б. Нуриев, А.И. Душенин, Н.М. Ибрагимов. – Текст : электронный // Теоретическая экономика. – 2025. - №11. - С.54-70. - URL: <http://www.theoreticaleconomy.ru> (Дата публикации: 30.11.2025)

Введение

В современном мире маркетинга объём данных продолжает расти экспоненциальными темпами. По данным исследования International Data Corporation (2020), объём данных, генерируемых маркетинговыми кампаниями, удваивается каждые два года, что свидетельствует о кардинально возросшей важности аналитики для бизнеса. В условиях этого информационного шума маркетологи сталкиваются с необходимостью эффективного анализа и интерпретации огромных массивов данных для принятия обоснованных стратегических решений.

Компании инвестируют значительные бюджеты в разнообразные маркетинговые каналы – от традиционных средств массовой информации, таких как телевидение и наружная реклама (билборды, реклама в транспорте), до современных цифровых платформ, включая социальные сети, поисковый маркетинг и performance-рекламу. В результате каждая рекламная кампания превращается в отдельную «точку данных», а их объединение и оценка эффективности становится все более сложной, но при этом крайне необходимой задачей.

Для понимания того, насколько успешно реализуются маркетинговые инициативы, требуется не только сбор данных, но и их глубокий анализ. В частности, важно установить, как отдельные элементы маркетингового микса влияют на ключевые бизнес-показатели: объём продаж, узнаваемость бренда (brand awareness), число активных пользователей (DAU – Daily Active Users), уровень клиентской лояльности и другие метрики. Традиционные методы анализа, такие как простое сравнение показателей до и после кампании или использование базовых отчетов, зачастую оказываются недостаточными из-за высокой фрагментации медиаландшафта, сложных взаимодействий между каналами и изменчивого поведения потребителей. Здесь на помощь приходит моделирование маркетингового микса (Marketing Mix Modeling, MMM) – мощный аналитический инструмент, предназначенный для распаковки эффекта каждого элемента микса и оценки их вклада.

Задача MMM заключается в том, чтобы разложить общую динамику продаж или другого целевого показателя на составляющие, объясняемые различными маркетинговыми и внешними факторами. Это включает в себя анализ влияния рекламных каналов (например, TV, Digital Media, ООН, блогеры), а также учет внешних факторов, таких как сезонность, экономическая ситуация или действия конкурентов. Современные MMM-модели также учитывают сложные взаимодействия между каналами, такие как синергия, или мультипликативное влияние (когда совместное использование нескольких каналов дает больший эффект, чем сумма их отдельных вкладов), эффекты насыщения (когда увеличение инвестиций в канал перестает приводить к пропорциональному росту результата) и эффекты отложенного воздействия (когда реклама не сразу приводит к действиям потребителей (например, покупке), потому что людям нужно время, чтобы запомнить сообщение, обдумать его и принять решение).

Моделирование маркетингового микса позволяет:

- Определить наиболее эффективные каналы, понять, какие каналы приносят наибольшую отдачу и почему. К примеру, анализ рекламной кампании американского обувного бренда Dockers показал, что синергия между TV и Digital Media может увеличить общую эффективность кампании на 20-30% [Naik & Raman, 2003].

- Оптимизировать распределение бюджета, т.е. перераспределять ресурсы между каналами для максимизации ROI (возврата на инвестиции) или минимизации CPA (стоимость одного целевого действия). К примеру, исследования рекламной кампании крупного коммерческого банка США показали, что оптимизация бюджета с учетом взаимодействий между каналами позволяет повысить ROI на 15-25% [Kireyev, et.al., 2016]. Однако сложность современных медиаландшафтов, включающих как традиционные, так и цифровые каналы, делает эту задачу крайне сложной.

– Прогнозировать эффект от будущих кампаний, т.е. оценивать, как изменения в маркетинговой стратегии повлияют на ключевые показатели. Особенно полезным для прогнозирования в условиях неопределённости является использование байесовских методов [Rossi, 2014].

– Принимать решения, основанные на данных: снизить риски и повысить точность планирования за счет использования аналитических моделей.

Цель данной работы – представить теоретические основы концепции моделирования маркетингового микса (МММ), охватывающие его историческое развитие, основные принципы, ключевые аспекты, а также инструменты и модели, применяемые для анализа и оптимизации маркетинговых стратегий.

История развития МММ

Понятие «маркетинговый микс» было впервые предложено в 1949 году американским маркетологом Нилом Борденом, который описал руководителя бизнеса как «миксера ингредиентов», сочетающего различные элементы маркетинговых стратегий для достижения прибыльности компании [Borden, 1964]. Этот образ подчеркивал необходимость интегрированного подхода к управлению маркетингом, где все компоненты взаимосвязаны и работают в синергии. В дальнейшем, в 1960-х годах, теория получила дальнейшее развитие благодаря работе Джерома Маккарти, который структурировал концепцию в виде «4Р» – Product (продукт), Price (цена), Place (место) и Promotion (продвижение) [McCarthy, 1960]. Эта модель стала классическим инструментом маркетинга, служащим основой для планирования и реализации маркетинговых стратегий, помогая предприятиям систематизировать свои усилия и фокусироваться на ключевых элементах.

С развитием технологий и появления новых каналов коммуникации, таких как телевидение, радио и наружная реклама, структура маркетингового микса расширялась и усложнялась. С появлением цифровых технологий начиная с конца XX века маркетинговый микс начал включать дополнительные элементы: Digital Media, социальные сети, блогеры, мобильные приложения и другие платформы коммуникации. Эти изменения привели к тому, что маркетинговый микс стал множественным набором элементов, сочетающим как традиционные, так и новые инструменты. В результате формирование эффективных стратегий требовало развития аналитических методов – моделирования маркетингового микса (МММ), который позволяет оценивать вклад каждого канала и взаимодействия между ними, а также принимать обоснованные решения о распределении маркетинговых ресурсов.

Одним из первых практических применений МММ стало использование регрессионных моделей для анализа эффективности рекламы на телевидении. В 1970-х годах крупные компании начали использовать статистические методы для оценки вклада рекламы в рост продаж, что стало одним из первых шагов к формализации оценки эффективности маркетинговых активностей [Naik & Ramap, 2003]. Тогда модель основывалась на простых линейных регрессиях, что позволило получить первые количественные оценки влияния различных каналов и стратегий.

С началом цифровой эпохи в 2000-х годах маркетинговое моделирование столкнулось с новыми вызовами. Появление интернета, социальных сетей, мобильных устройств и других цифровых платформ привело к резкому увеличению объёма данных и разнообразию каналов коммуникации. Эти изменения потребовали разработки новых, более гибких и мощных методов анализа. На этом этапе начали широко использоваться методы машинного обучения, такие как деревья решений, случайные леса и градиентный бустинг, которые позволяли моделировать сложные нелинейные зависимости и взаимодействия между каналами. Например, эти подходы давали возможность учитывать эффект насыщения, повторных контактов и синергий между медиаканалами.

Однако эти методы столкнулись с проблемой интерпретируемости – так называемого «черного ящика». Многие алгоритмы машинного обучения, несмотря на свою высокую точность, казались непонятными с точки зрения анализа и объяснения результатов, что не удовлетворяло требованиям маркетологов и менеджеров, которые нуждались в прозрачных рекомендациях на основе модели. В

результате возникла необходимость балансировать между мощностью моделей и их объяснимостью [Birim et al., 2024].

Цифровая революция полностью изменила ландшафт маркетинга, что потребовало развития новых подходов к МММ, учитывающих многоканальность, взаимодействия, ограниченность данных и динамику рынка. В этом контексте появились новые модели, использующие байесовские методы, а также методы глубокого обучения и гибридные подходы. Байесовские модели особенно ценны благодаря своей способности учитывать априорные знания, неопределенность и структурированные взаимодействия между каналами. Они позволяют моделировать не только средние эффекты, но и распределения вероятностей, что дает более реалистичную картину о воздействии маркетинговых усилий [Rossi, 2014].

Современные МММ-модели активно интегрируют данные из различных источников – социальных сетей, мобильных приложений, CRM-систем, платформ программной рекламы и других цифровых платформ. Такой комплексный подход помогает точнее оценить вклад каждого канала, выявлять скрытые зависимости и оптимизировать маркетинговые бюджеты. Внедрение байесовских методов и использование большого объема данных позволяют компаниям более точно отслеживать эффективность своих кампаний, восстанавливать коэффициенты для новых медиа и быстро адаптироваться к меняющимся условиям рынка [Sun, et. al., 2017].

На сегодняшний день развитие МММ включает также использование методов анализа больших данных (Big Data), искусственного интеллекта и автоматизированных систем рекомендаций. Эти инновации позволяют не только моделировать текущие показатели эффективности, но и прогнозировать будущие тренды, что становится важным конкурентным преимуществом. В эпоху цифровой трансформации интегрированные, гибкие и интерпретируемые аналитические инструменты становятся ключевыми для достижения бизнес-целей, повышения ROI маркетинга и удержания конкурентных позиций.

Современный маркетинговый микс представляет собой сложную систему, включающую разнообразные каналы и инструменты, каждый из которых выполняет свою уникальную роль в достижении маркетинговых целей. Эти каналы условно можно разделить на несколько основных категорий:

- Digital Media (цифровые медиа) – включает онлайн-рекламу, такую как display-реклама, видеореклама, активности в социальных сетях и мобильные приложения. Этот канал позволяет нацеливаться на конкретные аудитории, обеспечивать быстрый отклик и измерять эффективность в реальном времени.

- TV (телевизионная реклама) – остаётся одним из мощных инструментов для охвата широкой аудитории и повышения узнаваемости бренда. Особенно эффективна для формирования массового имиджа и доверия к продукту.

- ООН (Out-of-Home, наружная реклама) – включает билборды, рекламу в общественном транспорте и на других публичных местах. Эффективна для усиления присутствия бренда на целевых территориях и создания постоянного визуального напоминания.

- Блогеры и Influencer Marketing – использование влиятельных лиц для продвижения продукции и услуг. Этот канал особенно актуален для привлечения внимания молодёжной аудитории и повышения доверия через рекомендации.

- Performance-маркетинг – включает каналы, ориентированные на непосредственный результат, такие как контекстная реклама, поисковая оптимизация (SEO), email-маркетинг и партнерские программы. Эти инструменты позволяют оптимизировать маркетинговый бюджет, получая измеримый возврат инвестиций.

Каждый из перечисленных каналов обладает своими особенностями, сильными сторонами и ограничениями, и вносит уникальный вклад в общую маркетинговую стратегию. Для объективной оценки их эффективности необходимо применять различные статистические и аналитические

методы, которые учитывают сложные взаимодействия и взаимовлияния между каналами.

При оценке вклада каждого канала важно учитывать такие эффекты, как:

– Эффект насыщения – ситуация, когда с ростом активности в конкретном канале дополнительный прирост результатов становится всё меньшим. Например, после определенного уровня частоты показов рекламных объявлений эффективность начинает уменьшаться.

– Эффект отложенного воздействия – эффект, проявляющийся с задержкой во времени после проведения маркетинговых активностей. Например, рекламная кампания может стимулировать покупки через несколько дней или недель.

– Динамические особенности – возможные изменения в поведении потребителей, сезонность, конкурентное окружение и другие факторы, влияющие на результат.

Только комплексный подход с учетом этих факторов позволяет точно определить эффективность каждого канала, выявить синергии между ними и оптимизировать распределение маркетингового бюджета. Такой подход помогает повысить ROI и обеспечить достижение стратегических целей компании в условиях постоянно меняющегося цифрового ландшафта.

Методы моделирования маркетингового микса

Общее описание методов

Традиционно, маркетинговый микс моделирования (МММ) представляет собой статистический подход, основанный на применении регрессионного анализа для количественной оценки вклада различных маркетинговых каналов и факторов, влияющих на бизнес-показатели. В рамках этого подхода учитываются не только расходы на рекламу в различных каналах, но и такие внешние переменные, как сезонность, макроэкономические условия, действия конкурентов и другие факторы, оказывающие влияние на результаты компании [Lewis & Rao, 2015].

Наиболее простым и широко используемым методом для выполнения МММ является линейная регрессия. Она предполагает, что зависимая переменная, например, объём продаж, дневной активный пользователь (DAU) или количество органических установок, линейно зависит от нескольких независимых переменных, например, затрат на рекламу, промо-акций, программ лояльности и других маркетинговых активностей [Chornous & Farenjuk, 2021]. Этот подход легко реализуем и интерпретируем, что делает его популярным в практике маркетингового анализа. Однако классическая линейная регрессия сталкивается с рядом серьезных проблем и ограничений в условиях реальных маркетинговых кампаний и многоканальности. Во-первых, она часто недооценивает сложные взаимодействия между каналами, такие как синергии или отложенные эффекты, что приводит к неточным или искаженным оценкам их вклада. Она также предполагает независимость ошибок и отсутствие мультиколлинеарности среди объясняющих переменных, что в условиях многоканальных маркетинговых стратегий зачастую трудно соблюсти. В результате, модель может демонстрировать слабую способность захватывать сложные динамики рынка, что сказывается на качестве стратегических решений [Rimša, 2024].

Помимо регрессионных подходов, в моделировании маркетингового микса широко используются методы временных рядов, такие как ARIMA (AutoRegressive Integrated Moving Average) и SARIMA (Seasonal ARIMA). Они позволяют учитывать сезонность, тренды и временные зависимости, что особенно ценно при анализе продаж, сбыта или других бизнес-метрик, чувствительных к сезонным колебаниям. Эти модели помогают выделить долгосрочные тренды и специфические сезонные эффекты, оставляя в стороне шум и случайные флуктуации [Ng & Wang, 2024]. Тем не менее, применение таких моделей в контексте многоканального маркетинга сталкивается с рядом ограничений. ARIMA и SARIMA хорошо работают с временными зависимостями, но плохо справляются с высокоразмерными данными, сложными взаимодействиями между каналами или при наличии многочисленных факторов внешней среды. Они менее эффективны при моделировании нелинейных эффектов, насыщения или взаимодействий между каналами, что важно при анализе

современных мультимодальных маркетинговых стратегий.

В последние годы особое внимание уделяется байесовским методам, которые предлагают более гибкий инструментарий для моделирования маркетинговых миксов. Байесовский подход позволяет учитывать неопределенность в оценках, интегрировать априорные знания и лучше моделировать сложные взаимодействия между каналами и эффектами. Он особенно актуален в условиях быстро меняющихся рынков, где традиционные методы часто оказываются недостаточно адаптивными или неспособными полноценно учитывать недостающие или шумные данные [Wang et al., 2017]. Байесовские модели обеспечивают не только точечные оценки, но и распределения вероятностей параметров, что дает возможность полноценно оценивать уровни доверия и риски в принятых решениях. Они легче справляются с неполными данными, помогают выявлять скрытые зависимости и учитывать экспертные знания, что особенно важно при наличии ограниченных ресурсов или необходимости быстрого реагирования на динамику рынка. Такой подход делает байесовские методы мощным инструментом анализа в современных, сложных условиях многоканального маркетинга, позволяя принимать более обоснованные и устойчивые решения.

Ограничения классических подходов к МММ

Классические подходы к моделированию маркетингового микса (Marketing Mix Modeling, МММ), основанные на методах частотной статистики, сталкиваются с рядом значительных ограничений в условиях современной, многоканальной и цифровой маркетинговой среды. Эти ограничения существенно сказываются на их эффективности и точности, снижая качество результатов и усложняя принятие обоснованных решений. Ключевыми проблемами являются следующие:

– Проблема мультиколлинеарности. В современных маркетинговых кампаниях множество каналов и инструментов часто работают одновременно и тесно взаимодействуют друг с другом. Например, онлайн-реклама, поисковый маркетинг, социальные сети и офлайн-активности могут усиливать и дополнять друг друга, создавая взаимную корреляцию между маркетинговыми переменными. В классических регрессионных моделях такая мультиколлинеарность приводит к нестабильным и неопределённым оценкам коэффициентов, затрудняя точное определение вклада каждого отдельного канала. Это может вызвать как переоценку, так и недооценку влияния, что снижает доверие к моделям и приводит к ошибочным управленческим решениям [Chan & Perry, 2017].

– Ограниченность и «шумность» данных. В маркетинговых проектах нередко наблюдается проблема нехватки данных, их агрегированности по времени или географии, а также высокий уровень случайных колебаний и ошибок измерения. В таких условиях классические методы, основанные на предположении о чистоте и полноте данных, становятся менее надёжными. Результаты моделей могут оказаться смещёнными и не отражать реальную картину воздействия маркетинга на продажи или другие ключевые показатели. Кроме того, с ростом цифровой среды данные становятся более разрозненными и фрагментированными, что усложняет их интеграцию [Li & Kannan, 2014].

– Статичность и «точечные» оценки. Частотные статистические методы, используемые в классическом МММ, выдают параметрические оценки определёнными числами (точечными значениями). Однако эти оценки игнорируют степень неопределённости и вариабельности, присущей процессу моделирования. В реальной практике всегда существует множество факторов неопределённости, которые важно учитывать при принятии решений. Байесовские подходы предлагают альтернативу – они формируют апостериорные распределения параметров, позволяя лучше понимать диапазон возможных значений и уровни доверия, что существенно облегчает работу в условиях риска и неопределённости.

– Сложность включения априорных знаний. Часто маркетологи и аналитики обладают ценными экспертными знаниями о специфике рынков, особенностях каналов и характера целевой аудитории. В классических частотных моделях сложно формализовать и эффективно интегрировать такие априорные представления, особенно при ограниченности данных. Байесовские методы, напротив, изначально создавались для работы с априорной информацией, что позволяет более полно учитывать

экспертные знания и улучшать точность и интерпретируемость модели [Wigren & Cornell, 2019].

Недостаточная гибкость в моделировании сложных эффектов. Реальные маркетинговые процессы часто имеют нелинейный и динамический характер: эффекты насыщения (когда дополнительный бюджет дает всё меньший прирост), отложенные эффекты (carryover), синергия между каналами и сезонные колебания. Стандартные регрессионные модели, как правило, не способны полноценно отражать эти сложные зависимости и взаимосвязи, что ограничивает качество прогнозов и рекомендаций. Байесовские модели, обладая большей гибкостью, позволяют более эффективно моделировать такие эффекты, используя соответствующие распределения и иерархические структуры, что делает их особенно полезными для анализа современных многоканальных маркетинговых стратегий [Jin et al., 2017].

Преимущества байесовских методов

В отличие от классической линейной регрессии, байесовский подход позволяет наложить на коэффициенты модели некоторое заданное распределение, которое называется априорным. Предположим, что имеется следующая линейная модель:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \varepsilon$$

Если предварительно известно, что вклады β_1, \dots, β_p каждого признака не могут быть отрицательными (например, влияние расходов на рекламу на общий объём продаж), то для учёта этой информации можно наложить ограничения на эти параметры в виде распределения, которое определено на положительной полуоси, например, полунормальное (half-normal) с нулевым матожиданием и дисперсией σ :

$$p(q) = \frac{2}{\sigma\sqrt{2\pi}} e^{-\beta_i^2/(2\sigma^2)}, \quad \beta_i \geq 0$$

Априор $p(\sigma)$ действует как «мягкое» ограничение, смещая оценки коэффициентов к наиболее правдоподобным значениям. Например, использование гауссовского априора эквивалентно L_2 -регуляризации в ридж-регрессии [Bishop, 2006].

Байесовское моделирование, основанное на теореме Байеса, предлагает уникальные преимущества для Marketing Mix Modeling (MMM), позволяя более точно оценивать влияние маркетинговых каналов и прогнозировать результаты кампаний. Одним из главных преимуществ байесовского подхода является возможность интеграции априорных знаний в модель. В отличие от классических методов, которые полагаются исключительно на данные, байесовское моделирование позволяет учитывать экспертные мнения, исторические данные или результаты предыдущих исследований. Это особенно полезно в MMM, где маркетологи часто обладают ценными инсайтами о поведении потребителей или эффективности каналов. Байесовские методы позволяют комбинировать данные с априорными ожиданиями, что делает модели более устойчивыми к недостатку данных или их шумности» [Gelman, et al., 2020]. Это особенно актуально для новых или слабо представленных медиаканалов, где данных может быть недостаточно для точной оценки.

Кроме того, байесовское моделирование предоставляет не только точечные оценки, но и полное распределение вероятностей для параметров модели. Это позволяет маркетологам оценивать неопределенность прогнозов и принимать более обоснованные решения. Например, вместо того чтобы просто сказать, что ROI определенного канала составляет 2,5, байесовская модель может показать, что с вероятностью 95% ROI находится в диапазоне от 2,0 до 3,0. Байесовский подход позволяет мыслить в терминах распределений, а не фиксированных значений, что делает его более реалистичным для анализа сложных систем [McElreath, 2020; Kruschke, 2015]. В контексте MMM это означает, что маркетологи могут лучше оценивать риски и планировать бюджеты с учетом неопределенности.

Маркетинговая среда характеризуется высокой динамичностью: изменением потребительских предпочтений, конкурентной ситуации и эффективности каналов коммуникации. Байесовские модели обладают преимуществом легкости обновления при поступлении новых данных, что делает

их особенно пригодными для долгосрочного мониторинга и оптимизации маркетинговых стратегий. Благодаря возможности непрерывного обновления, эти методы эффективно применимы к анализу временных рядов и динамических систем. В связи с этим байесовские подходы являются особенно актуальными для моделирования маркетинговых миксов (МММ), где требуется постоянная актуализация моделей в ответ на изменения рыночных условий.

В современных маркетинговых кампаниях каналы часто взаимодействуют друг с другом, создавая синергетические эффекты или, наоборот, конкурируя за внимание потребителей. Байесовское моделирование позволяет учитывать межканальные взаимодействия, используя иерархические структуры и многомерные распределения [Zhang & Vaver, 2017]. Благодаря этому можно эффективно моделировать взаимосвязи между каналами, включая мультипликативные эффекты в регрессионных уравнениях и учитывая долгосрочные воздействия [Tellis, 2006], такие как эффект переноса (carryover effect). Это способствует получению более точных оценок вклада каждого канала в продажи и повышает качество прогнозирования эффективности маркетинговых стратегий.

Эффекты динамики и взаимодействия в маркетинге

Мультипликативные эффекты и синергия между каналами

В реальной практике маркетинговые каналы редко функционируют изолированно – их эффекты зачастую переплетаются, создают и усиливают друг друга, формируя мультипликативные эффекты и синергию. Это означает, что воздействие одного канала влияет на эффективность других, что делает динамику маркетинговых стратегий более сложной, но и более доходной при правильном учете. Понимание и анализ этих взаимодействий позволяют маркетологам более точно оценить вклад каждого канала, а также обеспечить оптимальное распределение маркетингового бюджета, что существенно повышает общую отдачу от инвестиций.

В рамках моделирования маркетингового микса (МММ) мультипликативные эффекты возникают, когда воздействие одного рекламного канала усиливает эффект другого. Например, реклама на телевидении может значительно увеличить узнаваемость бренда и доверие потребителей, что в свою очередь усиливает эффективность цифровых каналов, таких как онлайн-реклама или электронная почта. В результате, усилия, направленные на один канал, не только приносят собственные результаты, но и повышают эффективность других каналов, создавая синергетический эффект.

Такое взаимодействие часто приводит к тому, что общий эффект маркетинговой кампании превышает сумму эффектов отдельных каналов при их независимом функционировании. Игнорирование этих взаимодействий может привести к серьезным искажениям в оценке эффективности маркетинговых каналов, что в итоге ведет к неэффективному распределению ресурсов, занижению или завышению вклада отдельных каналов и, как следствие, снижению общего ROI (возврата на инвестиции). Поэтому учет мультипликативных эффектов и синергии становится ключевым элементом современных методов оценки эффективности, анализа и планирования маркетинговых кампаний.

Для учёта эффектов взаимодействия рекламных каналов можно использовать регрессионную модель в мультипликативной постановке [Pandey, et. al., 2021]:

$$y_t = \exp(\alpha) \cdot \beta_1 A_t \cdot \beta_2 B_t \cdot \varepsilon_t$$

где:

y_t – значение целевой переменной в момент времени t ;

A_t, B_t – расходы на рекламы разных видов в момент времени t ;

α, β_1, β_2 – неизвестные коэффициенты модели;

ε_t – ошибка в момент времени t .

Эта модель основывается на предположении, что увеличение расходов на один рекламный канал может усиливать эффективность другого, создавая мультипликативный эффект. В отличие

от аддитивных моделей, где влияние каждого канала складывается независимо, данная модель подчеркивает взаимное влияние каналов друг на друга. Например, увеличение бюджета на онлайн-рекламу не только увеличивает непосредственно показатели продаж, но и усиливает эффективность оффлайн-акций, большей степенью связанной с телевидением или радио.

Для упрощения оценки параметров этой модели и повышения ее интерпретируемости используют логарифмическое преобразование, что переводит модель в линейную форму:

$$\ln(y_t) = \alpha + \tilde{\beta}_1 \ln(A_t) + \tilde{\beta}_2 \ln(B_t) + \tilde{\varepsilon}_t$$

Данная трансформация, основанная на логарифмировании переменных, позволяет использовать стандартные методы линейной регрессии для оценки параметров модели. Это обеспечивает удобство и прозрачность в процессе анализа, так как находится на базе широко применяемых и хорошо изученных статистических техник.

Кроме того, преобразование дает возможность интерпретировать полученные коэффициенты как эластичности, т.е. как процентное изменение целевой переменной (например, объем продаж или узнаваемость бренда) при увеличении расходов на рекламный канал на 1%. Например, если коэффициент для логарифма расхода на цифровую рекламу равен 0,3, это означает, что при увеличении затрат на цифровую рекламу на 1% ожидается рост целевой переменной примерно на 0,3%. Такая интерпретация очень полезна для маркетолога, поскольку она позволяет легко оценить относительную важность каждого канала и сравнить их эффективность, не вдаваясь в сложные расчетные формулы.

Также стоит отметить, что использование логарифмов также помогает уменьшить влияние выбросов и неравномерных масштабов данных, делая модель более устойчивой и интерпретируемой. В результате, исследование влияния каналов становится более интуитивным и понятным, что способствует принятию обоснованных решений относительно распределения маркетингового бюджета.

Эффект воронки

В современной маркетинговой практике взаимодействие между оффлайн- и онлайн-каналами играет важнейшую роль в формировании потребительского поведения и влияет на эффективность рекламных стратегий. Одним из ключевых явлений, которое необходимо учитывать в моделях маркетинговых медиа-кампаний (МММ), является так называемый эффект воронки (funnel effect). Этот эффект описывает сложное влияние одних каналов рекламы на другие, а также их совместное влияние на конечные потребительские действия.

В частности, оффлайн-маркетинг, такой как телевидение, наружная реклама, радио или печатные СМИ, способен создавать осведомленность и стимулировать интерес потребителей к продукту или бренду. Эти ранние контакты и узнаваемость становятся начальным этапом в потребительской воронке продаж. В результате, существенно возрастает активность в онлайн-каналах, таких как поисковая оптимизация, контекстная реклама, социальные сети или электронная коммерция, особенно в нижних этапах воронки, когда потребитель уже склонен к покупке. Например, телевизионная реклама может повысить узнаваемость бренда, что приводит к росту поисковых запросов, связанных с этим брендом, а также к увеличению конверсий в онлайн-магазинах и рекламных платформах. Такой «катализатор» со стороны оффлайн-медиа формирует «воронку», которая переводит потребителя от первоначального контакта с брендом к финальной покупке [Briggs et al., 2005].

Учет эффекта воронки особенно важен при моделировании маркетинговых медиа-кампаний, поскольку он позволяет более точно оценить вклад каждого канала в общий результат. Без учета такого взаимодействия можно недооценить или переоценить эффективность отдельных каналов, что ведет к неправильному распределению маркетинговых бюджетов и стратегий. Например, игнорирование влияния оффлайн-рекламы на онлайн-активность может привести к тому, что крупные инвестиции

в онлайн-каналы будут казаться менее эффективными, чем они есть на самом деле, поскольку их результат зачастую является зависящим от предварительных каналов.

Однако, при попытках количественной оценки взаимодействия между каналами возникает важная статистическая проблема – эндогенность. В эконометрике этот термин обозначает ситуацию, когда одна переменная влияет на другую, а при этом сама находится под воздействием обратной связи или скрытых факторов. Стандартные линейные модели, такие как обычная регрессия, предполагают независимость объясняющих переменных, и использование их в условиях эндогенности приводит к получению смещенных и некорректных оценок коэффициентов. Это, в свою очередь, искажает понимание реальных статистических закономерностей.

Для преодоления этих трудностей широко применяются методы Causal Inference – подходы, позволяющие установить причинно-следственные связи между переменными, минимизируя влияние промежуточных факторов. Одним из ключевых элементов этой концепции является использование инструментальных переменных, которые помогают «выделить» чистое влияние интересующей переменной, например, затраты на рекламный канал, на целевую переменную, исключая влияние внешних факторов и обратных связей [Pearl, 2010].

В концепции Causal Inference, как правило, рассматривают следующие переменные:

- Y – целевая переменная (например, объём продаж);
- T – переменная, влияние на Y которой необходимо оценить (например, расходы на контекстную рекламу);
- W – переменные, влияющие и на Y, и на T (например, ТВ-реклама);
- X – переменные, влияющие только на Y (например, сезонные факторы, инициативы, связанные исключительно с продуктом).

Схематично взаимодействие этих переменных можно представить следующим образом (см. рис. 1):




Рисунок 1 – Схема взаимодействия переменных в концепции Causal Inference

Источник: построено авторами.

Для оценки вклада переменной T в изменение Y применяется последовательный алгоритм, основанный на подходах Causal Inference, который помогает исключить влияние косвенных или «лишних» факторов. Один из таких алгоритмов можно представить следующим образом [Funk, 2011]:

- Построение модели $q(X, W)$ – зависимости Y от X и W (прогнозируется значение целевой переменной, учитывая влияние «независимых» факторов):

$$q(X, W) = E(Y | X, W)$$

- Построение модели $f(W)$ – зависимости T от W (фиксируется влияние факторов, влияющих на расходы, что позволяет отделить влияние рекламных затрат от остальных эффектов):

$$f(W) = E(T | W)$$

- Выделение «чистой» динамики Y и T (из исходных значений вычитаются прогнозируемые значения, полученные с помощью ранее построенных моделей, чтобы устранить влияние внешних

факторов):

$$\widehat{Y} = Y - q(X, W) \quad \widehat{T} = T - f(W)$$

– Оценка влияния \widehat{Y} и \widehat{T} (определяется вклад интересующей переменной, с минимальным смещением, обусловленным «лишними» факторами):

$$\widehat{Y} = \alpha + \beta \cdot \widehat{T} + \varepsilon$$

Этот подход делает возможным более точную и надежную оценку эффективности рекламных вложений, учитывая сложные взаимодействия и предотвращая искажения, вызванные эндогенностью. В результате, маркетолог и аналитик получают инструмент для принятия обоснованных решений, оптимизации медиамикса и стратегического планирования с учетом причинно-следственных связей в маркетинговых данных.

Эффект насыщения

Эффект насыщения (saturation effect) отражает тот факт, что после достижения определённого уровня рекламной активности, дальнейшее увеличение инвестиций в рекламу приводит к снижению предельной отдачи. Это связано с ограниченной ёмкостью рынка: по мере насыщения сегмента аудитории, большинство потенциальных потребителей уже были охвачены рекламной кампанией, и дополнительные вложения начинают давать всё меньший прирост в эффективности. Такой эффект также обусловлен убывающей предельной полезностью рекламы: после достижения определённого уровня, каждый дополнительный рубль или просмотр уже не приносит такого же результата, как в начале кампании.

Моделировать эффект насыщения можно с помощью различных подходов, одним из которых является использование логистической функции:

$$S(x_t) = \frac{1 - e^{-\mu x_t}}{1 + e^{-\mu x_t}}$$

где:

μ – параметр, определяющий форму кривой насыщения, а также точку полунасыщения (чем больше μ , тем резче граница насыщения и более острый спад отдачи после определённого уровня затрат);

x_t – показатель рекламной активности (например, показы, клики, затраты медиаканала);

$S(x_t)$ – значение эффекта насыщения, варьирующееся от 0 до 1 (0 означает отсутствие насыщения, а 1 – полное насыщение).

Данная формула позволяет учесть, что при очень малых значениях μ и x_t эффект растёт почти линейно – по мере увеличения активности отдача увеличивается пропорционально вложениям. Однако по мере роста μ и x_t кривая приобретает S-образную форму: сначала эффект быстро возрастает, затем замедляется и достигает плато, что отражает насыщение рынка. Это особенно важно при планировании рекламных стратегий, так как понимание точки насыщения помогает оптимизировать инвестиции: избегать излишних затрат, которые не приносят соответствующего результата, и сосредоточиться на достижении эффективных уровней активности. Применение подобной модели помогает более реалистично оценивать эффективность рекламных кампаний, адаптировать бюджеты и избегать перерасходов, а также учитывать особенности поведения рынка и потребителей.

На рис. 2 показано, что при значениях параметра $\mu=0,5$ и $\mu=0,1$ кривая насыщения растёт медленно и достигает своего предела только при больших значениях переменной x_t . При $\mu=1$ кривая демонстрирует умеренный наклон, что отражает баланс между плавностью роста и скоростью достижения насыщения. В то время как при более высоких значениях $\mu=2$ и $\mu=3$ кривые становятся более крутыми, достигая насыщения при меньших значениях x_t . Таким образом, увеличение параметра μ соответствует более резкому росту эффекта с меньшими значениями входных

переменных и более быстрому приближению к насыщению.




Рисунок 2 – Кривые насыщения: S-образная кривая для разных μ

Источник: построено авторами.

Эффект отложенного воздействия

Эффект отложенного воздействия (Adstock) отражает тот факт, что воздействие рекламных сообщений не ограничивается только моментом их показа, а продолжает оказывать влияние на последующие периоды времени. Это обусловлено тем, что потребители могут запоминать рекламу, обдумывать её и реагировать с задержкой, что делает важным моделировать накопительный эффект рекламы в течение времени. В различных моделях медиапланирования учитывают, что эффект от рекламных воздействий не исчезает мгновенно, а сдержанно «накапливается» и затухает, создавая так называемый эффект Adstock.

В литературе представлены разные подходы к моделированию Adstock, среди которых наиболее широко используются геометрический Adstock и модель, основанная на распределении Вейбулла. Эти методы позволяют более точно учитывать динамику воздействия рекламы и повышают качество прогнозирования эффективности маркетинговых кампаний.

Геометрический Adstock – это наиболее распространенный и простой метод учёта долгосрочного влияния рекламной активности, который был предложен С. Бродбентом [Broadbent, 1984]. Данный подход предполагает, что эффект рекламы затухает экспоненциально с фиксированной скоростью. Математически это выражается формулой:

$$\text{Adstock}_t = X_t + \lambda \cdot \text{Adstock}_{t-1}$$

где:

$\lambda \in (0,1)$ – коэффициент затухания, показывающий, какая доля эффекта переносится из предыдущего периода в текущий;

X_t – рекламные расходы в момент t .

Например, при $\lambda=0,75$ значительная часть эффекта (75%) переносится в следующий период, что означает, что остаточный эффект сохраняется достаточно долго, но постепенно исчезает. Этот подход прост в реализации и широко применяется в практике медиа-планирования, поскольку легко

интегрируется в аналитические модели.

В развернутом виде, геометрический Adstock можно представить как бесконечную сумму, где каждый предыдущий эффект уменьшается в геометрической прогрессии [Коуск, 1954]:

$$\text{Adstock}_t = \sum_{k=0}^{\infty} \lambda^k \cdot X_{t-k}$$

Это соответствует предположению о постоянной скорости затухания, которая часто бывает оптимальной в ситуации, когда эффект от рекламы убывает экспоненциально во времени.

Альтернативный и более гибкий подход к моделированию Adstock основывается на распределении Вейбулла, впервые предложенном шведским математиком В. Вейбуллом [Weibull, 1951] для анализа прочности материалов. В контексте медиапланирования эта модель описывает распределение задержки реакции аудитории на рекламное воздействие, что особенно ценно при моделировании сложных сценариев и продуктов.

Её функция плотности вероятности позволяет смоделировать, как эффект рекламы накапливается и затухает во времени. Форма затухания зависит от параметров формы (α) и масштаба (β):

$$w_t = \frac{\alpha}{\beta} \cdot \left(\frac{t}{\beta}\right)^{\alpha-1} \cdot e^{-\left(\frac{t}{\beta}\right)^{\alpha}}$$

где:

w_t – вес воздействия в момент t ;

β – параметр масштаба, определяющий растяжение или сжатие кривой во времени;

α – параметр масштаба, задающий «растяжение» эффекта во времени (чем выше α , тем дольше влияние).

Эта формула позволяет моделировать как экспоненциальное, так и S-образное затухание воздействия, что делает модель Вейбулла более универсальной по сравнению с простым геометрическим подходом.

Параметр формы β определяет тип кривой распределения. Например, если $\beta < 1$, то распределение наклонено к началу. Это означает, что эффект быстро достигает своего пика сразу после запуска кампании или воздействия, а затем мгновенно убывает. Такой сценарий характерен для кратковременных, очень интенсивных мероприятий, где влияние оказывается максимально сильным сразу, а затем быстро исчезает. Примеры таких случаев включают всплески в социальных сетях, когда вирусное видео или хештег быстро набирает популярность, достигает пика за очень короткий промежуток времени, а затем его влияние исчезает. Также это подходит для рекламных акций или предложений, проводимых за ограниченный период (например, распродажи или акции «ONE DAY ONLY»).

Если $\beta = 1$, то модель Вейбулла превращается в экспоненциальное затухание, аналогичное классической геометрической модели (Adstock). В этом случае эффект снижается со временем с постоянной скоростью, то есть реакция на воздействие уменьшается в течение времени равномерно и независимо от предыдущих уровней воздействия. Такой сценарий характерен для рекламных кампаний или стимулов, у которых влияние постепенно и стабильно ослабевает, например, при стандартной рекрутской акции или рекламной кампании с равномерным эффектом, убывающим с постоянным темпом.

Если $\beta > 1$, то кривые приобретают S-образную форму: эффект сначала усиливается, достигает запаздывающего пика, а затем постепенно снижается. Такой сценарий характерен для более сложных процессов, например, вирусных кампаний, когда влияние постепенно растёт по мере обдумывания информации потребителями, достигает максимума с задержкой и затем затухает [Morais, et. al., 2018].

Это происходит потому, что потребители сначала накапливают и осмысливают информацию, а после пика интерес угасает. Например, в случае приобретения автомобиля или крупных бытовых устройств потребитель обычно собирает информацию, консультируется с друзьями, тестирует и сравнивает варианты, прежде чем сделать окончательный выбор. Поэтому реклама должна «запуститься» за достаточное время до принятия решения, а её влияние должно усиливаться по мере формирования мнения и интереса потребителя.

Модель Вейбулла с параметром $\beta \approx 3$ применяется при моделировании задержек и цепных реакций распространения информации в социальных сетях и вирусных кампаниях. В таких сценариях наблюдается эффект «взрыва» популярности, когда ролик или сообщение спустя некоторое время после запуска начинают резко набирать просмотры, репосты и упоминания. Например, видео может стать вирусным и достигнуть широкой аудитории через 5–7 дней, что обусловлено активным распространением пользователями, что создает эффект цепной реакции [Lambrech, 2013].

Знание распределения времени отклика и характера распространения позволяет маркетологам лучше планировать рекламные действия [Tellis, 2006]. Например, если известно, что эффект достигает пика примерно через неделю, можно оптимизировать интервалы между последовательными рекламными воздействиями, чтобы поддерживать или усиливать общий эффект кампании. Это особенно важно при запуске вирусных или сценарных рекламных стратегий, где правильное время воздействия может значительно увеличить охват и повысить эффективность бюджета. Кроме того, моделирование задержек помогает определить оптимальные точки повторных рекламных контактов, чтобы не «перегружать» аудиторию и избегать снижения эффективности из-за «перекрывания» эффектов или усталости.

Заключение

В данной работе подробно рассмотрены ключевые аспекты оценки воздействия различных рекламных каналов на эффективность маркетинговых кампаний, с особым акцентом на необходимость учета сложных взаимодействий и динамических факторов, влияющих на результаты. Среди важных аспектов выделяются эффекты воронки продаж и синергетические взаимодействия каналов, которые могут значительно усиливать или ослаблять общий эффект кампании в зависимости от их сочетания и последовательности применения. Кроме того, важную роль играют временные факторы, такие как затухание воздействия, задержки реакции аудитории и сезонные колебания, что приводит к необходимости учитывать нелинейную и вариативную природу влияний. Эти сложности требуют построения более точных, надежных и гибких моделей маркетингового микса, способных учитывать взаимодействия между каналами, временную динамику и структурные особенности данных. В результате, такие модели позволяют принимать обоснованные управленческие решения, оптимизировать распределение рекламных бюджетов и повышать рентабельность маркетинговых инвестиций.

На сегодняшний день байесовские методы остаются одними из наиболее востребованных и эффективных инструментов моделирования в сфере маркетинга благодаря своей способности гибко учитывать сложные зависимости, интегрировать априорные знания и управлять неопределенностью в моделях. В отличие от простых методов регуляризации, байесовский подход позволяет строить сложные иерархические модели, которые отражают структурные особенности данных, например, внутренние различия между сегментами аудитории или регионами. Особенно важной чертой байесовских моделей является возможность моделирования временных зависимостей, таких как сезонные эффекты, тренды, циклы и задержки реакции, что помогает лучше понять динамику кампаний и определить оптимальные временные окна для проведения рекламных воздействий.

Также байесовские методы позволяют учитывать пространственную вариативность, например, различия в эффективности каналов в различных регионах или странах. Использование иерархических априоров в таких моделях способствует объединению информации между группами данных, сохраняя при этом их локальные особенности. Например, группировка коэффициентов

по регионам с общим гиперраспределением позволяет учесть, что регионы могут иметь сходные характеристики, но при этом сохранять уникальные нюансы, что уменьшает риск переобучения и повышает обобщающую способность модели.

Эта структурированная гибкость делает байесовский подход особенно ценным для комплексного анализа и оптимизации маркетинговых стратегий. Он позволяет не только оценить эффективность каждого канала, но и понять, как их взаимодействия и зависимости влияют на итоговый результат, а также обеспечить более точное прогнозирование и принятие решений. В конечном итоге, внедрение байесовских методов способствует построению более устойчивых, адаптивных и оптимальных маркетинговых моделей, что особенно важно в условиях быстро меняющегося рынка, роста конкуренции и увеличения объёма данных.

СПИСОК ЛИТЕРАТУРЫ

1. Birim S., Kazancoglu I., Mangla S. K., Kahraman A., Kazancoglu Y. The derived demand for advertising expenses and implications on sustainability: a comparative study using deep learning and traditional machine learning methods // *Annals of Operations Research*. 2024. Vol. 339. P. 131-161.
2. Bishop C. Pattern Recognition and Machine Learning // *Journal of Electronic Imaging*. 2006. Vol. 16(4). P. 140-155.
3. Borden N. H. The concept of the marketing mix // *Journal of Advertising Research*. 1964. Vol. 4(2). P. 7-12.
4. Briggs R., Krishnan R., Borin N. Integrated Multichannel Communication Strategies: Evaluating the Impact on Consumer Purchase Decisions // *Journal of Advertising Research*. 2005. Vol. 45(4). P. 375-387.
5. BNg & Wang, 2024 S. Modelling with Adstock // *Journal of the Market Research Society*. 1984. Vol. 26(4). P. 295-312.
6. Chan D., Perry M. Challenges and opportunities in media mix modeling // Google Inc. 2017, April 14.
7. Chornous G., Farenjuk Y. Marketing mix modeling for pharmaceutical companies on the basis of data science technologies // *Access Journal*. 2021. Vol. 2(3). P. 274-289.
8. Funk M. J. Doubly Robust Estimation of Causal Effects // *American Journal of Epidemiology*. 2011. Vol. 173(7). P. 761-767.
9. Jin Y., Wang Y., Sun Y., Chan D., Koehler J. Bayesian methods for media mix modeling with carryover and shape effects // Google Inc. 2017, April 14.
10. Kireyev P., Pauwels K., Gupta S. Do Display Ads Influence Search? Attribution and Dynamics in Online Advertising // *International Journal of Research in Marketing*. 2016. Vol. 33(3). P. 475-490.
11. Koyck L. M. Distributed Lags and Investment Analysis. Amsterdam: North-Holland, 1954. 111 p.
12. Kruschke J. K. Doing Bayesian Data Analysis: A Tutorial with R, JAGS, and Stan. Academic Press, 2015. 749 p.
13. Lambrecht A., Tucker C. When Does Retargeting Work? // *Journal of Marketing Research*. 2013. Vol. 50(5). P. 561-576.
14. Lewis R. A., Rao J. M. The unfavorable economics of measuring the returns to advertising // *Quarterly Journal of Economics*. 2015. Vol. 130(4). P. 1941-1973.
15. Li H., Kannan P. K. Attributing Conversions in a Multichannel Online Marketing Environment // *Marketing Science*. 2014. Vol. 33(1). P. 40-56.
16. McCarthy J. E. Basic Marketing: A Managerial Approach. Homewood, IL: Richard D. Irwin, 1960. 770 p.
17. McElreath R. Statistical Rethinking: A Bayesian Course with Examples in R and Stan. CRC Press, 2020. 483 p.
18. Morais J., Thomas-Agnan C., Simioni M. Impact of advertising on brand's market shares in the automobile market: a multi-channel attraction model with competition and carryover effect // *TSE Working Paper*. 2018. No. 18(878).
19. Naik P. A., Raman K. Understanding the Impact of Synergy in Multimedia Communications // *Journal of Marketing Research*. 2003. Vol. 40(4). P. 375-388.
20. Ng E., Wang Z., Dai A. Bayesian Time Varying Coefficient Model with Applications to Marketing Mix Modeling // arXiv preprint arXiv:2106.03322v4. 2024.
21. Pandey S., Gupta S., Chhajed S. Marketing Mix Modeling (MMM) – Concepts and Model Interpretation // *International Journal of Engineering Research & Technology (IJERT)*. 2021. Vol. 10(6). P. 784-793.
22. Pearl J. An Introduction to Causal Inference // *The International Journal of Biostatistics*. 2010. Vol. 6(2). P. 1-62.
23. Rimša R. Marketing Mix Modelling using Bayesian statistics (Master's thesis). Vilnius University,

Vilnius. 2024, 38 p.

24. Rossi P. E. Bayesian Statistics and Marketing. Wiley, 2014. 384 p.

25. Sun Y., Wang Y., Jin Y., Chan D., Koehler J. Geo-level Bayesian hierarchical media mix modeling //

Google Inc. 2017, April 14.

26. Tellis J. Modeling marketing mix // The handbook of marketing research: uses, misuses, and future advances. 2006. P. 506-522.

27. Wang Y., Jin Y., Sun Y., Chan D., Koehler J. A hierarchical Bayesian approach to improve media mix models using category data // Google Inc. 2017, April 14.

28. Weibull W. A Statistical Distribution Function of Wide Applicability // Journal of Applied Mechanics. 1951. Vol. 18(3). P. 293-297.

29. Wigren R., Cornell F. Marketing Mix Modelling: A comparative study of statistical models (Master's thesis). Linköping University, Department of Computer and Information Science, 2019. 122 p.

30. Zhang S. S., Vaver J. Introduction to the Aggregate Marketing System Simulator // Google Inc. 2017, April 14.

Marketing mix modelling as a tool for evaluating the effectiveness of advertising campaigns

The study was carried out with financial support from the Russian Science Foundation within the framework of scientific project No. 23-18-00409

Nuriev Islam Babash Ogly

Postgraduate student, Media Analyst at VK,
Novosibirsk State University, Novosibirsk, Russian Federation
E-mail: i.nuriev@nsu.ru

Dushenin Alexander Igorevich

Candidate of Economic Sciences, Lecturer¹, Junior Research Fellow²,
¹Institute of Economics and Industrial Engineering, Siberian Branch of the Russian Academy of Sciences, Novosibirsk, Russian Federation, Novosibirsk, Russian Federation
²Novosibirsk State University, Novosibirsk, Russian Federation
E-mail: a.dushenin@nsu.ru

Ibragimov Naimdzhon Mulaboevich

Doctor of Economic Sciences, Associate Professor, Professor^{1,3}, Leading Research Fellow²
¹Novosibirsk State University, Novosibirsk, Russian Federation
²Institute of Economics and Industrial Engineering, Siberian Branch of the Russian Academy of Sciences, Novosibirsk, Russian Federation
³Novosibirsk State Technical University, Novosibirsk, Russian Federation
E-mail: naimdjon.ibragimov@nsu.ru

KEYWORDS

marketing mix modelling, Bayesian approach, synergy effect, funnel effect, saturation effect, Adstock effect, advertising channels, causal inference

ABSTRACT

In the modern business environment, companies make significant investments across diverse marketing channels, ranging from traditional media (television advertising, outdoor advertising, print media, etc.) to contemporary digital formats (contextual advertising, influencer marketing, social networks, email campaigns, etc.). This wide array of channels creates a complex system of marketing communications, which in turn necessitates precise and systematic assessment of each individual channel's contribution, as well as their interactions, in achieving business objectives and maximizing marketing investment efficiency. This paper presents the theoretical foundations of the Marketing Mix Modeling (MMM) concept, aimed at modeling and analyzing the influence of individual components of marketing strategies on key business indicators such as sales, profit, or market share. The research pays special attention to studying the effects of interactions between marketing channels, as well as their dynamic aspects: synergy effects, saturation, and Adstock. These considerations facilitate a more accurate evaluation of temporal sequences and relationships between investments and outcomes. Furthermore, the work provides a detailed examination of Bayesian methods. These techniques allow for effective integration of prior knowledge and expert assessments into the models, which is especially important in conditions of limited data, high multicollinearity between channels, or uncertainties. Bayesian approaches not only enhance the accuracy of estimates but also ensure reliable interval estimations, and they can easily model complex, hierarchical, and nonlinear interactions between components of the marketing mix, making the analysis more flexible and adaptable to various conditions.